PROJEÇÃO DE CUSTOS E O MÉTODO DE SIMULAÇÃO DE MONTE CARLO: O CASO DA FUNDAÇÃO SALUTE

Luiz João Corrar

Resumo:

Este artigo tem por objetivo mostrar como o Método de Simulação de Monte Carlo pode ser útil no tratamento de um dos aspectos importantes da análise de decisão que é a modelagem da incerteza. Foram apresentados os conceitos básicos de simulação e do método de Monte Carlo. Este método é usado no processo de simulação probabilística. Permite, essencialmente simular o comportamento de sistemas que dependem de fatores aleatórios. A utilização dessa técnica depende do conhecimento dos tipos de distribuição de probabilidades das variáveis componentes do modelo. É essencial para sua operacionalização a utilização de processamento eletrônico dos dados. Foi aplicada a técnica de simulação de Monte Carlo em uma Fundação que cuida dos Planos de Saúde dos empregados de diversas empresas. Através dos resultados apresentados foi possível efetuar projeções de custos relativos os planos de saúde dessas empresas bem como determinar os riscos associados as essas projeções.

Palavras-chave:

Área temática: *Custos e Tomada de Decisões*

5.11. PROJEÇÃO DE CUSTOS E O MÉTODO DE SIMULAÇÃO DE MONTE CARLO: O CASO DA FUNDAÇÃO SALUTE

Luiz João Corrar
Doutor em Controladoria e Contabilidade
Universidade de São Paulo - USP
Av. Prof. Luciano Gualberto, 908 – Cidade Universitária
CEP: 05508=900 – Fone: (011) 818.5820
e-mail: ljcorrar@usp.br
Professor Doutor do Departamento de Contabilidade e Atuária da FEA/USP.

RESUMO

Este artigo tem por objetivo mostrar como o Método de Simulação de Monte Carlo pode ser útil no tratamento de um dos aspectos importantes da análise de decisão que é a modelagem da incerteza.

Foram apresentados os conceitos básicos de simulação e do método de Monte Carlo. Este método é usado no processo de simulação probabilística.
Permite, essencialmente simular o comportamento de sistemas que dependem de fatores aleatórios.

A utilização dessa técnica depende do conhecimento dos tipos de distribuição de probabilidades das variáveis componentes do modelo. É essencial para sua operacionalização a utilização de processamento eletrônico dos dados.

Foi aplicada a técnica de simulação de Monte Carlo em uma Fundação que cuida dos Planos de Saúde dos empregados de diversas empresas.

Através dos resultados apresentados foi possível efetuar projeções de custos relativos os planos de saúde dessas empresas bem como determinar os riscos associados as essas projeções.

1. Introdução

As transformações pelas quais passa o mundo dos negócios são mais significativas do que nunca: surgem os mercados globais, acelera-se o processo de desenvolvimento tecnológico, reconfiguram-se as estruturas organizacionais.

Essas mudanças estão incrementando, de forma notável, os riscos que afetam as empresas e instituições públicas e privadas.

Os gestores devem estar cada vez mais preparados para entender o atual desenvolvimento dos negócios de forma a conduzir melhor suas empresas em meio a esse vertiginoso processo de mudanças, de competitividade e de riscos.

Os gestores necessitam instrumentalizar-se com técnicas que lhes permitam identificar e avaliar os riscos que afetam suas decisões além de métodos que os ajudem nas projeções de variáveis econômicas.

Como veremos neste artigo a estatística e a pesquisa operacional surgem como instrumentos auxiliares úteis ao processo de tomada de decisão.

2. Problema

De acordo com Mosimann (1993) o processo de gestão caracteriza-se essencialmente por ser um processo de tomada de decisão. Esse processo ocorre tanto a nível da empresa como um todo, quanto de cada uma de suas partes.

Clemen (1996) aponta diversas fontes básicas de dificuldades para o processo de tomada de decisões. Uma delas se deve ao fator incerteza inerente a cada situação.

O processo de análise de decisões envolve, segundo Clemen (1996), a identificação da situação de decisão de forma clara e o perfeito entendimento dos objetivos cruciais a serem alcançados.

O entendimento dos objetivos conduz à identificação das diversas alternativas para o seu atingimento bem como a melhor forma de mensurar os seus resultados.

O passo seguinte seria decompor o problema de forma a entender a sua estrutura. O entendimento das diversas partes do problema conduz à melhor forma de tratar o fator incerteza inerente a cada modelo, o que leva ao desenvolvimento de modelos mais adequados a cada situação de decisão. Nessa fase torna-se muito importante a consideração do modelo de preferenciais dos tomadores de decisão. A modelagem matemática e a escala de preferenciais provavelmente conduzirão à melhor alternativa.

Uma vez construído o modelo é importante submetê-lo à análise de sensibilidade para que se possa auferir como os diversos tipos de alterações no modelo afetam os resultados.

Como a análise de decisão é um processo iterativo , após a análise de sensibilidade é possível se detectar a necessidade de redefinição dos objetivos e inclusão

de novos objetivos não contemplados inicialmente no modelo. Assim, pode-se identificar novas alternativas e pode-se apontar para alterações no modelo de incerteza e de preferenciais. Feitas as devidas correções trata-se da implementação da alternativa escolhida.

A análise de decisão de forma acurada e sistemática pode criar uma vantagem competitiva para a empresa.

O objetivo deste trabalho é tratar de um dos aspectos importantes da análise de decisão que é a modelagem da incerteza.

Não abordaremos todas as formas de modelagem da incerteza mas, trataremos especificamente sobre os modelos de simulação de Monte Carlo.

Será feita uma aplicação prática da técnica de simulação, aplicada a uma entidade administradora de planos de saúde.

3. Conceitos Básicos

3.1 Simulação

O termo simulação é utilizado para se referir a "uma técnica que imita a operação de um sistema do mundo real durante todo o tempo" (Winston, 1984, p. 1183).

Os modelos em geral representam a realidade enquanto que os modelos de simulação a imitam, uma vez que apresentam menos simplificações da realidade que os modelos em geral (Turban e Meredith, 1994, p.670).

Assim, "pela observação do comportamento do modelo durante os experimentos, o analista é capaz de fazer referências sobre o possível comportamento do sistema no mundo real" (Watson, 1989 p.2).

Conforme Shannon (1975, p.2) os modelos de simulação se constituem numa metodologia experimental e aplicada que procura:

1. Descrever o comportamento de um sistema;
2. Construir teorias ou hipóteses que explicam o comportamento observado;
3. Usar essas teorias para prever o comportamento futuro, ou seja, os efeitos que serão produzidos pelas mudanças no sistema ou nos seus métodos de operação.

3.2. Sistema

Um sistema pode ser definido como um conjunto de elementos que estão inter relacionados e que interagem uns com os outros procurando atingir um objetivo (Watson, 1989, p.2).

Os sistemas geralmente tendem a ser dinâmicos, ou seja, seu estado muda o tempo todo. "O estado de um sistema é o conjunto de variáveis necessárias para descrever a posição do sistema a qualquer tempo" (Winston, 1994, p.1184).

Como exemplo de sistema temos o caso de uma entidade que cuide de planos de saúde. Aqui o sistema compreende os empregados das empresas atendidas pelo plano de saúde, as entidades médicas conveniadas, os servidores da entidade que cuida dos planos. A medida que os empregados entram ou saem do plano, por exemplo, a posição do sistema muda.

Para descrever essas mudanças na posição, necessitamos de um conjunto de variáveis denominadas de estado. Por exemplo, número de empregados atendidos, custo de atendimento, recursos disponibilizados pelas empresas, valores pagos pelos empregados, etc.

3.3. Tipos de Modelos

Os modelos podem ser classificados em físicos que se constituem em representações físicas da realidade, ou simbólicos quando usam símbolos para representar a realidade. Entre os modelos simbólicos temos os verbais que usam palavras para representar a realidade e os modelos matemáticos que usam símbolos matemáticos. (Watson, 1989, p.4).

3.4. Características dos Modelos Matemáticos

Os modelos matemáticos podem ter diversas características dependendo do seu propósito, modo de análise e tratamento da aleatoriedade. (Watson, 1989, p.4)

Quanto ao propósito o modelo pode ser de otimização ou descritivo. Os de otimização são usados na resolução de problemas administrativos que envolvem por exemplo, maximização de lucros ou minimização de custos. Os modelos descritivos tem o propósito de descrever o comportamento de um sistema sem se preocupar com a otimização. Os modelos de simulação são classificados como descritivos. Estes não visam a otimização diretamente. Procuram mostrar em que condições um sistema opera de maneira mais eficaz e eficiente.

Quanto ao modo de análise os modelos matemáticos podem ser analíticos ou numéricos. Os modelos analíticos utilizam as técnicas matemáticas e estatísticas tradicionais (análise de regressão, cálculo diferencial, etc), para efetuar a análise de forma a obter informações exatas sobre o sistema modelado. Os modelos numéricos substituem essas operações matemáticas e estatísticas por um grande número de simples operações computacionais. Os modelos analíticos tem preferência em relação aos numéricos porque são mais precisos e eficientes. Entretanto, devido à complexidade dos sistemas muitas vezes é utilizado o método numérico. Os modelos de simulação são usados para análise de sistemas complexos e assim utilizam os métodos numéricos.

Com respeito à aleatoriedade, praticamente todos os sistemas são probabilísticos, ou seja, o comportamento do sistema não pode ser previsto com certeza porque certo grau de aleatoriedade está sempre presente. Um modelo probabilístico procura captar a natureza probabilística do sistema utilizando como *input* os dados probabilísticos e gerando resultados probabilísticos.

Um modelo determinístico não contém variáveis aleatórias, ou seja, as variáveis apresentam valores definidos. Embora a maior parte dos sistemas sejam probabilísticos,

muitos modelos matemáticos são determinísticos e são muito usados porque apresentam menor dificuldade e proporcionam informação satisfatória para o processo decisório.

Segundo Winston (1994, p. 1185) os modelos de simulação podem ser determinísticos ou estocásticos. São determinísticos quando não contém variáveis aleatórias. São estocásticos quando contém uma ou mais variáveis aleatórias.

3.5. Tipos de Simulação Probabilística

Segundo Turban e Meredith (1994, p. 73) a simulação probabilística é um tipo de simulação onde uma ou mais variáveis independentes é probabilística. Isto é, apresentam uma certa distribuição de probabilidades. Existem duas categorias de distribuição de probabilidades: a distribuição discreta e a distribuição contínua.

- a distribuição discreta refere-se a uma situação onde as variáveis podem assumir somente um número finito de valores.
- a distribuição contínua refere-se a uma situação envolvendo variáveis com um número ilimitado de valores possíveis que seguem uma função densidade tal como a distribuição normal.

A simulação probabilística é conduzida com a ajuda de uma técnica denominada de Monte Carlo.

3.6. O Método de Monte Carlo

Os sistemas administrativos de decisão em condições de risco apresentam elementos de chance em seu comportamento. Como tal, podem ser simulados com a ajuda da técnica de Monte Carlo. Esta não se constitui num modelo de simulação em si, embora tenha se tornado sinônimo de simulação probabilística. É um mecanismo usado no processo de simulação probabilística (Turban e Meredith, 1994, p.675).

Esta técnica é denominada de Monte Carlo porque utiliza um processo aleatório, tal como um lançamento de dados ou o girar de uma roleta, para selecionar os valores de cada variável em cada tentativa (Morse, 1986). Este método permite, essencialmente, simular o comportamento de processos que dependem de fatores aleatórios (Sobol, 1983).

O método de Monte Carlo originou-se do trabalho de Von Neumann e Ulan, desenvolvido em 1940, e constituía-se numa técnica que foi utilizada para selecionar processos de blindagem em reatores nucleares (Naylor et alii, 1996).

Para que se possa entender como esse método funciona será apresentado um exemplo bastante simplificado, obtido em Corrar (1992), envolvendo apenas uma variável aleatória. Antes serão apresentados alguns termos técnicos.

- ***Distribuição Uniforme***

Uma distribuição uniforme é aquela em que cada valor da variável tem exatamente a mesma chance de ocorrer (Turban e Meredith, 1994, p. 675). Veja o exemplo no Quadro 1 e representação gráfica na Fig. 1.

Quadro 1
Distribuição Uniforme

Volume de Vendas	Probabilidade
1	0,25
2	0,25
3	0,25
4	0,25

Como se vê no Quadro 1 os diversos volumes de vendas (1, 2, 3,4) apresentam sempre a mesma probabilidade de ocorrência (0,25)

Fig. 1 - Gráfico de Distribuição Uniforme

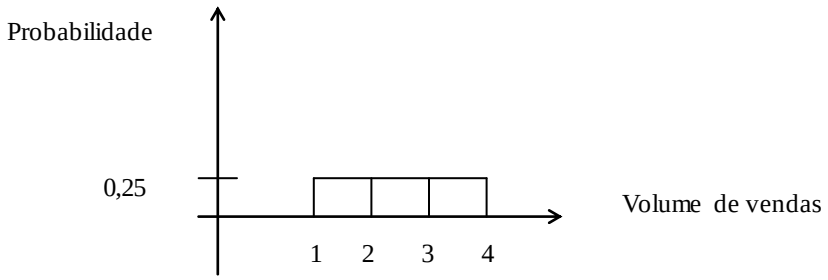

Número aleatório é um número tomado, aleatoriamente, de uma população de números uniformemente distribuídos. Isto é, cada número na população tem a mesma chance de ser selecionado. Por exemplo, numa população de números de 0 a 9, poderíamos obter números aleatórios com um dígito, ou seja: 5, 2, etc.

Suponha, por exemplo, que determinado produto apresente a distribuição de probabilidades para o volume de vendas obtida historicamente, conforme Quadro 2, colunas 1 e 2 (Shanblin e Stevens, 1979, pg. 176).

Quadro 2 – Distribuição de Probabilidades do Volume de Vendas do Produto

Volume de Vendas por dia	**Probabilidade Simples**	**Probabilidade Acumulada**	**Intervalo de números aleatórios**
0	0,05	0,05	00 – 04
1	0,10	0,15	05 – 14
2	0,15	0,30	15 – 29
3	0,30	0,60	30 – 59
4	0,25	0,85	60 – 84
5	0,15	1,00	85 – 99

A empresa deseja prever os volumes de vendas para os próximos 10 dias. O passo inicial é construir a distribuição de probabilidade acumulada, conforme consta na

coluna 3 do Quadro 2. Esses valores são obtidos pela soma das distribuições de probabilidades simples.

Tomando-se por base a distribuição acumulada constrói-se a coluna 4, do Quadro 2. Os valores ali constantes representam os intervalos de classe da função de distribuição acumulada e refletem as probabilidades dos diversos volumes de venda. Aos valores assim obtidos dá-se o nome de intervalo de números aleatórios, e mostram o limite inferior e o superior, respectivamente, de cada intervalo de classe. Verifica-se que representam números que variam de 0 a 99.

O passo seguinte é gerar números aleatoriamente a partir de uma população de números compreendidos entre 0 e 99. Esses números poderiam ser obtidos através do girar de uma roleta ou de diversas outras formas.

Suponhamos que através do uso de um programa de computador tenham sido gerados os números aleatórios de acordo com a ordem apresentada no Quadro 3, linha 1:

Quadro 3 – Vendas Previstas Para os Próximos 10 dias

Números Aleatórios	14	74	24	87	07	45	26	66	26	94
Volume de Vendas Previsto	1	4	2	5	1	3	2	4	2	5
Dias	1	2	3	4	5	6	7	8	9	10

Verifica-se que o primeiro número gerado, ou seja 14, corresponde ao intervalo de números aleatórios 05 – 14 (Quadro2, coluna 4) que se refere por sua vez ao volume de vendas de 1 unidade por dia (Coluna 1 do Quadro 2). Assim, através desse processo é possível estimar os volumes de vendas dos próximos 10 dias, conforme apresentado no Quadro 3.

3.7. A Determinação das Distribuições de Probabilidades

As distribuições de probabilidades podem ser obtidas de dados históricos. Nesse caso deve-se pressupor que os dados passados refletirão o comportamento futuro.

Entretanto, em muitos casos os dados passados não estão disponíveis ou apresentam muita deficiência. Nesses casos, o dirigente necessita elaborar estimativas subjetivas que reflitam suas expectativas quanto ao comportamento futuro dessas variáveis. As estimativas subjetivas podem ser obtidas a partir da experiência do próprio dirigente ou de um grupo de especialistas (Boucinhas, 1972, p.51).

3.8. Tipos de Distribuição de Probabilidades

As variáveis do modelo podem ser descritas por distribuições discretas ou contínuas.

Uma variável aleatória é considerada discreta se toma valores que podem ser contados (Stevenson, 1981, p.97).

Uma variável aleatória é considerada contínua quando pode tomar qualquer valor de determinado intervalo (Stevenson, 1981, p.98).

Um exemplo de variável discreta é a que segue uma distribuição uniforme, que conforme já foi definido anteriormente é aquela em que cada um dos distintos valores da variável tem a mesma chance de ocorrer.

A distribuição uniforme pode-se referir também a uma variável contínua. Quando uma variável aleatória pode assumir qualquer valor numa escala contínua entre dois pontos, de tal maneira que nenhum valor seja mais provável que o outro, então as probabilidades associadas à variável podem ser descritas pela distribuição uniforme(Stevenson, 1981, p.134). Graficamente, ela é representada por um retângulo limitado por 2 pontos, **a** e **b**, que representam o intervalo de resultados possíveis. Vide Fig. 2 .

Fig. 2 – Distribuição Uniforme Contínua

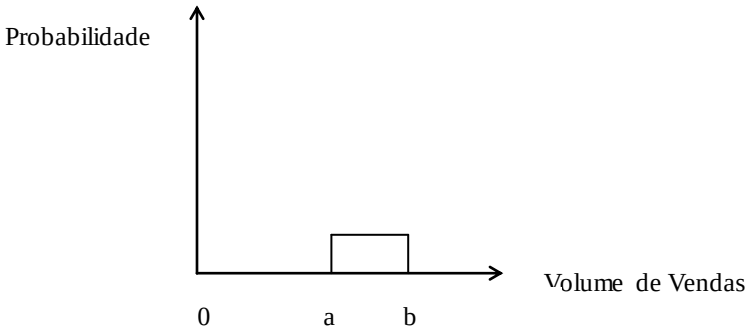

O exemplo mais conhecido de distribuição contínua, entretanto, é a distribuição normal cujo gráfico se assemelha muito a um sino (Fig. 3). É suave, unimodal e simétrica em relação à sua média. Outra característica importante é que uma distribuição normal fica completamente especificada por 2 parâmetros: sua média e seu desvio padrão(Stevenson, 1981, p. 137).

Fig. 3 Distribuição Normal

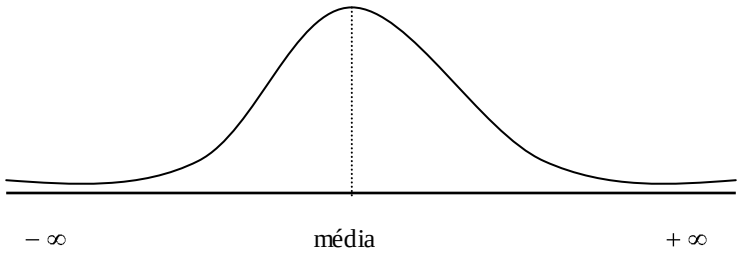

4. O caso da Fundação Salute

4.1. Apresentação do Problema

A Fundação Salute é uma entidade instituída para cuidar dos Planos de Saúde dos empregados de diversas empresas denominadas patrocinadoras. Estas tem hoje cerca de 15.000 empregados que contribuem com R$150,00 por mês deduzidos da folha de pagamento. Estabeleceu-se que esse valor deverá permanecer constante para os próximos 12 meses, uma vez que a taxa de inflação estimada para esse período deverá estar próxima de zero.

Entretanto, as contribuições dos empregados são insuficientes para ressarcimento das obrigações com entidades médicas conveniadas.

Através da análise do comportamento dessa variável verificou-se que o valor médio mensal das obrigações com as entidades médicas é de R$300,00. Constatou-se também que a taxa de crescimento médio mensal dessas obrigações é de 0,5% com desvio padrão de 4%.

Portanto, as obrigações apresentam valores bem superiores ao das contribuições dos empregados. A diferença se constitui em custos que deverão ser cobertos pelas patrocinadoras.

O Sr. Lourival renomado atuário, é o responsável pelos cálculos atuariais da Fundação Salute. Ele foi encarregado pelo presidente Sr. Adelmo para juntamente com a Sra. Rose, responsável pela área de controladoria, elaborarem os estudos de projeção de custos para os próximos 12 meses, bem como apresentarem os riscos associados às projeções.

O Sr. Lourival e a Sra. Rose verificaram que o número de empregados cobertos pelo plano sofrerão alterações ao longo dos próximos 12 meses, por diversos motivos. Previram através de análise de dados históricos que o número de empregados cobertos pelo plano pode sofrer uma variação uniforme durante o ano, podendo apresentar uma redução máxima de 2% e um acréscimo máximo de 3%.

De posse dessas informações estavam preocupados em escolher um método para efetuar as projeções de custos.

Tanto o Sr. Lourival como a Sra. Rose estão frequentando um curso denominado MBA – Gestão Financeira e Atuarial desenvolvido pela FIPECAFI/USP. Durante uma das aulas ouviram o professor falar que é possível utilizar uma técnica de previsão que leva em conta os diferentes tipos de distribuição de probabilidades das variáveis envolvidas (nesse caso, como se viu, o número de empregados apresenta uma distribuição uniforme e as obrigações uma distribuição normal), bem como permite estabelecer os níveis de riscos associados às previsões. Esta técnica é denominada simulação de Monte Carlo.

4.2. Tratamento dos Dados

Os dados são introduzidos numa planilha eletrônica do programa Excel Versão 7.0. Esse programa apresenta uma opção para gerar números aleatórios conforme diversos tipos de distribuição de probabilidades.

No caso, foram utilizadas a distribuição normal para a variável obrigações e a uniforme para o número de empregados.

O quadro 4 apresenta as Projeções de Custos da Fundação para o período de 12 meses.

Quadro 4 - Projeção dos Custos da Fundação para o período de 12 meses.

Mês	Número de Empregados	Contribuições dos Empregados($)	Obrigação Média por Empregado($)	Total das Obrigações ($)		Custo para a Empresa ($)
1	14796	2219390	301,50	4460906		2241516
2	14730	2209508	302,93	4462153		2252644
3	14668	2200264	304,45	4465837		2265574
4	14425	2163730	306,08	4415094		2251364
5	14529	2179281	307,54	4468076		2288795
6	14462	2169324	309,10	4470239		2300915
7	14319	2147899	310,61	4447789		2299890
8	14511	2176711	312,24	4530998		2354287
9	14851	2227622	313,76	4659591		2431969
10	14974	2246141	315,36	4722329		2476188
11	15398	2309733	316,92	4880018		2570285
12	15434	2315053	318,52	4915881		2600828
TOTAL						28334255

Faremos alguns comentários sobre essas projeções:

- Coluna 2: apresenta a projeção do número de empregados para o período levando em conta que essa variável apresenta uma distribuição uniforme, portanto, os números aleatórios gerados obedecerão essa distribuição. Parte dos 15.000 empregados atuais e considera uma redução máxima de 2% e aumento máximo de 3% durante o período.
- Coluna 3: projetado o número de empregados e considerando que a contribuição por empregado é constante, ou seja, R$150,00 por mês, chegou-se ao total das contribuições dos empregados.
- Coluna 4: obrigação média por empregado. Considerando que as obrigações para com os conveniados apresentam distribuição normal com média de R$300,00, aumento médio mensal de 0,5% e desvio padrão de 4%, projetaram-se as obrigações médias por empregado para o período.
- Coluna 5: total das obrigações. É o resultado do produto das obrigações médias por empregado pelo número de empregados.
- Coluna 6: Custo para a empresa. Este custo representa a diferença entre o valor total das obrigações menos as contribuições dos empregados. Os valores mensais foram somados chegando ao total do período.

Como as variáveis são aleatórias o modelo poderia gerar uma população infinita de resultados possíveis para o custo da empresa.

Assim, se gerarmos esses resultados inúmeras vezes estaremos formando uma grande amostra dessa população. Uma vez gerada uma amostra suficientemente grande é possível utilizá-la para fazer estimativas do comportamento da população e de suas características.

No caso foram feitas 500 replicações do modelo gerando uma amostra bastante grande.

4.3. Análise dos Resultados

Os dados da amostra foram resumidos no Quadro 5.

Quadro 5 – Resumo Estatístico

CUSTOS DA EMPRESA	
Média	29835069
Erro padrão	40593
Mediana	29820325
Moda	#N/D
Desvio padrão	907688
Variância da amostra	823898010878
Curtose	-0,41
Assimetria	0,02
Intervalo	4755217
Mínimo	27473200
Máximo	32228417
Soma	14917534689
Contagem	500
Nível de confiança(95.0%)	79754

Analisando os valores ali apresentados verifica-se que a menor estimativa de custo é de cerca de R$27,5 milhões, o que representaria a melhor situação. A pior situação seria representada pelo valor máximo da estimativa de cerca de R$32,2 milhões. O custo médio estimado é de aproximadamente R$29,8 milhões, com um desvio padrão de R$0,9 milhões, que representa cerca de 3% da média.

Os graus de assimetria e curtose se aproximam de zero indicando que a distribuição dos custos se aproxima de uma normal.

4.4. Avaliação do Risco

Os resultados já apresentados (média, desvio padrão, mínimo, máximo) constituem-se em informações úteis ao processo decisório. Entretanto, o gestor, gostaria de conhecer as probabilidades de ocorrências desses cenários (mínimo e máximo). Essa informação proporcionaria uma medida de risco quanto às projeções efetuadas.

É possível obter essas informações adicionais construindo-se a Distribuição de Frequência (Quadro 6) e o Histograma (Fig. 4) a partir da amostra gerada de 500 observações.

Quadro 6 – Distribuição de Frequência

Intervalos *de Custos*	*Freqüência*	*% cumulativo*	% no Intervalo
27500	1	,2%	,2%
28500	38	7,8%	7,6%
29000	46	17,0%	9,2%
29500	103	37,6%	20,6%
30000	98	57,2%	19,6%
30500	88	74,8%	17,6%
31000	72	89,2%	14,4%
31500	40	97,2%	8,0%
32000	11	99,4%	2,2%
Mais	3	100,0%	,6%

Figura 4 – Histograma

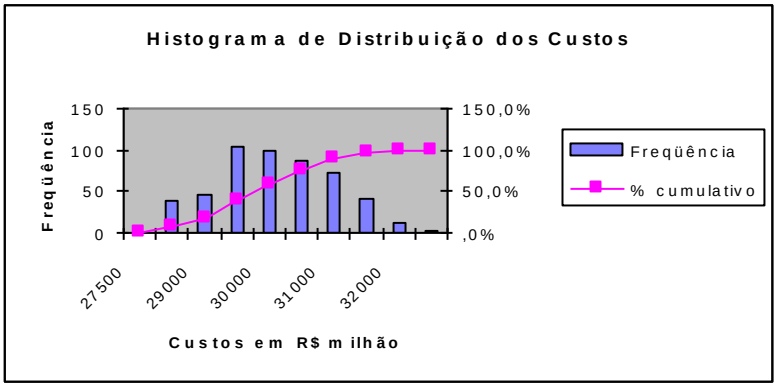

Analisemos a primeira linha do Quadro 6 - Distribuição de Frequência. Verifica-se que há apenas 1 caso (coluna 2) do total de 500 casos possíveis em que o custo projetado pode ser igual ou inferior a R$27,5 milhões. Em percentagem cumulativa isso representa apenas 0,2% (3ª coluna).

Vamos analisar por exemplo, a 4ª linha. Há 103 casos do total de 500 possíveis em que o custo projetado poderá ser superior a R$29,5 milhões e inferior ou igual a R$30 milhões. Significa que há uma probabilidade de 20,6% (4ª coluna) dos custos projetados se situarem nesse intervalo.

Verifica-se também que (linha 7) em termos cumulativos, a probabilidade dos custos ficarem abaixo de R$31 milhões é de 89,2%. Portanto, há uma probabilidade de

apenas 10,8% dos custos serem superiores a R$31 milhões. Essa informação tranqüiliza o Sr. Wilson, responsável pela área financeira.

Essas informações podem ser visualizadas também através da Fig. 4 - Histograma de Distribuição dos Custos.

4.5. Outras Estimativas

Os resultados apresentados referem-se a amostra de 500 observações, enquanto que a verdadeira população apresenta um número infinito. Mas com base nessa amostra pode-se estimar o verdadeiro custo médio projetado para a população. Como o tamanho da amostra é maior que 30 observações pode-se tomar por base o Teorema do Limite Central e estabelecer o intervalo de confiança de 95% para o verdadeiro custo projetado da população utilizando a seguinte expressão:

$$\text{Probabilidade}\left\{\bar{X} \pm 1{,}96\ \frac{S}{\sqrt{n}}\right\} \geq 0{,}95$$

onde

$\bar{X}$ = média da amostra (500 observações)

S = desvio padrão da amostra

n = tamanho da amostra

Substituindo a expressão pelos respectivos valores:

$$\text{Probabilidade}\left\{29{,}8 \pm \frac{0{,}907}{\sqrt{500}}\right\} \geq 0{,}95$$

Os resultados indicam que podemos estar 95% confiantes que o verdadeiro custo médio da população se situará entre R$29,7 milhões e R$29,9 milhões.

5. Conclusões

Para a construção de modelos mais adaptáveis à realidade é necessário considerar que as variáveis componentes podem assumir um comportamento aleatório.

Os modelos determinísticos continuam a apresentar grande utilidade. Entretanto, os modelos probabilísticos, por serem mais ajustados à realidade, dotam a administração de instrumentos mais úteis ao processo de tomada de decisões porque permitem estimar as probabilidades que apresentam certa variável de atingir uma determinada faixa de valores.

A simulação de Monte Carlo é uma técnica que usa um processo estocástico para determinar, através de múltiplas tentativas, a natureza das distribuições de probabilidades que seriam difíceis de se determinar pelos procedimentos estatísticos .

Uma das grandes vantagens da simulação de Monte Carlo é que os modelos que a utilizam podem acomodar diferentes graus de complexidade. Além disso, esta técnica permite que se incorpore a relação de dependência entre as variáveis envolvidas.

Como aplicação prática apresentou-se um modelo em que se utiliza o método de Monte Carlo ao caso de projeção de custos de uma entidade que tem por objetivo a administração de planos de saúde. Considera-se que as variáveis envolvidas eram aleatórias com determinadas distribuições de probabilidades.

Através desse caso pode-se mostrar a utilidade da simulação de Monte Carlo na geração de amostras que servem de base para projeções e inferências sobre o comportamento dos custos.

A partir da amostra gerada foi possível estabelecer as probabilidades associadas às diversas faixas de custo. Com isso foi possível definir os riscos associados às projeções.

Finalizando, parece ficar demonstrado neste trabalho que a técnica de simulação pode ser de grande utilidade no processo de tomada de decisões por parte da administração.

6. Bibliografia

BOUCINHAS, J.F. DA COSTA . A aplicação de Modelos ao Processo de Planejamento na Empresa. Tese de Doutoramento. Universidade de São Paulo, Faculdade de Economia, Administração e Contabilidade, 1972.

CORRAR, L.J. Análise de Relações Custo-Volume para Multiprodutos em Condições de Incerteza. Tese de Doutoramento. Universidade de São Paulo. Faculdade de Economia, Administração e Contabilidade, 1990.

CORRAR, L. J. O Modelo Econômico da Empresa em Condições de Incerteza: Aplicação do Método de Simulação de Monte Carlo. Anais do XVI ENANPAD, Volume 2. Canela - RS, 1992.

MORSE, WAYNE J. e ROTH, HAROLD P. *Cost Accounting: Processing, Evaluating and Using Cost Data*. Third Edition. Addison Wesley Publishing Company, 1986.

NAYLOR, T.H.; BALINTFY, J.L.; BUNDICK, D.S. e CHU, K. *Computer Simulation Techniques*. Wiley & Sons, 1966.

SHANBLIN, JAMES E. e STEVENS. JR.; G.T. Pesquisa Operacional. Editora Atlas, 1979.

SHANON, ROBERT E. *Systems Simulation: The Art or Science*. Englewood Cliff. E.U.A. Prentice Hall, 1975.

SOBOL, I. O Método de Monte Carlo. Editora Mir, 1983.

STEVENSON, WILLIAM J. Estatística Aplicada à Administração. São Paulo. Harper & Row, 1981.

TURBAN, EFRAIN e MEREDITH, JACK. R. *Fundamental of Management Science*, Irwin, 6th , 1994.

WATSON, HUGH. J. & BLACKSTONE, JR. JOHN H. *Computer Simulation*, 2ª Edição. E.U.A. John Wiley & Sons, Inc, 1989.

WINSTON, NAYNEL . *Operations Reesearch: Aplications and Algorithmus*. Dux Bury Press, 3th, 1994.